

### 3.4 大数定理和中心极限定理

在数学中大家都注意到过这样的现象:有的时候一个有限的和很难求,但一经取极限由有限过渡到无限,则问题反而好办.例如,若要对某一有限范围的  $x$  计算和

$$a_n(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \cdots + \frac{x^n}{n!}$$

则在  $n$  固定但很大时,很难求.而一经取极限,则有简单的结果:

$\lim_{n \rightarrow \infty} a_n(x) = e^x$ . 利用这个结果, 当  $n$  很大时, 可以把  $e^x$  作为  $a_n(x)$  的近似值.

在概率论中也存在着这种情况. 如果  $X_1, X_2, \dots, X_n$  是一些随机变量, 则  $X_1 + \dots + X_n$  的分布, 除了若干例外, 算起来很复杂. 因而自然地会提出问题: 可否利用极限的方法来进行近似计算? 事实证明这不仅可能, 且更有利的是: 在很一般的情况下, 和的极限分布就是正态分布. 这一事实增加了正态分布的重要性. 在概率论上, 习惯于把和的分布收敛于正态分布的那一类定理都叫做“中心极限定理”. 在本节 3.4.2 段中我们将列述这类定理中最简单, 然而也是最重要的一种情况.

在概率论中, 另一类重要的极限定理是所谓“大数定理”. 它是由概率的统计定义“频率收敛于概率”引伸而来. 为描述这一点, 我们把频率通过一些随机变量的和表示出来. 设做了  $n$  次独立试验, 每次观察某事件  $A$  是否发生. 按(1.20)式定义随机变量  $X_i, i = 1, \dots, n$ . 则在这  $n$  次试验中事件  $A$  一共出现了  $X_1 + \dots + X_n$  次, 而频率为

$$p_n = (X_1 + \dots + X_n)/n = \bar{X}_n \quad (4.1)$$

若  $P(A) = p$ , 则“频率趋于概率”就是说, 在某种意义下(详见下文), 当  $n$  很大时  $p_n$  接近  $p$ . 但  $p$  就是  $X_i$  期望值, 故也可以写成:

当  $n$  很大时  $\bar{X}_n$  接近于  $X_i$  的期望值.

按这个表述, 问题就可以不必局限于  $X_i$  只取 0, 1 两个值的情形. 事实也是如此. 这就是较一般情况下的大数定理. “大数”的意思, 就是指涉及大量数目的观察值  $X_i$ , 它表明这种定理中指出现象, 只有在大量次数的试验和观察之下才能成立. 例如, 一所大学可能包含上万名学生, 每人有其身高. 如果我们随意观察一个学生的身高  $X_1$ , 则  $X_1$  与全校学生的平均身高  $a$  可能相去甚远. 如果我们观察 10 个学生的身高而取其平均, 则它有更大的机会与  $a$  更接近些. 如观察 100 个, 则其平均又能更与  $a$  接近些. 这些都是我们日常经验中所体验到的事实. 大数定理对这一点从理论的高

度给予概括和论证.

### 3.4.1 大数定理

**定理 4.1** 设  $X_1, X_2, \dots, X_n, \dots$  是独立同分布的随机变量, 记它们的公共均值为  $a$ . 又设它们的方差存在并记为  $\sigma^2$ . 则对任意给定的  $\epsilon > 0$  有

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - a| \geq \epsilon) = 0 \quad (\bar{X}_n \text{ 见(4.1)}) \quad (4.2)$$

(4.2)这个式子指出了“当  $n$  很大时,  $\bar{X}_n$  接近  $a$ ”的确切含义:它的意义是概率上的,不同于微积分意义下某一列数  $a_n$  收敛于数  $a$ . 按(4.2)只是说:不论你给定怎样小的  $\epsilon > 0$ ,  $\bar{X}_n$  与  $a$  的偏离有否可能达到  $\epsilon$  或更大呢? 这是可能的,但当  $n$  很大时,出现这种较大偏差的可能性很小,以致当  $n$  很大时,我们有很大的(然而不是百分之百的)把握断言  $\bar{X}_n$  很接近  $a$ . 拿上面学生身高的那个例子说,即使你抽了 100 个以至 1000 个学生,你有没有绝对的把握说,这 100 个或 1000 个学生的平均身高一定很接近全校学生的平均身高  $a$  呢? 没有,因为理论上不能排除这种可能性:你碰巧把全校中那 100 或 1000 个最高的学生都抽出来了. 这时你计算的  $\bar{X}_n$  就会与  $a$  有很大差距. 但我们也能相信,如果抽样真是随机的(每一学生有同等被抽出的机会),则随着抽样次数增多,这样的可能性会愈来愈小. 这就是(4.2)式的意思. 像(4.2)式这样的收敛性,在概率论中叫做“ $\bar{X}_n$  依概率收敛于  $a$ ”.

为了证明定理 4.1,需要下面的概率不等式:

**马尔科夫不等式** 若  $Y$  为只取非负值的随机变量,则对任给常数  $\epsilon > 0$  有

$$P(Y \geq \epsilon) \leq E(Y)/\epsilon \quad (4.3)$$

设  $Y$  为连续型变量,密度函数为  $f(y)$ . 因为  $Y$  只取非负值,有  $f(y) = 0$  当  $y < 0$ . 故

$$E(Y) = \int_0^{\infty} yf(y)dy \geq \int_{\epsilon}^{\infty} yf(y)dy$$

因为在  $[\epsilon, \infty)$  内总有  $y \geq \epsilon$ , 且  $\int_{\epsilon}^{\infty} f(y) dy$  就是  $P(Y \geq \epsilon)$ . 故

$$E(Y) \geq \int_{\epsilon}^{\infty} yf(y) dy \geq \epsilon \int_{\epsilon}^{\infty} f(y) dy = \epsilon P(Y \geq \epsilon)$$

即(4.3). 当  $Y$  为离散型时证明相似, 请读者自己完成.

不等式(4.3)的一个重要特例为

**契比雪夫不等式.** 若  $\text{Var}(Y)$  存在, 则

$$P(|Y - EY| \geq \epsilon) \leq \text{Var}(Y)/\epsilon^2 \quad (4.4)$$

为证此, 只须在(4.3)式中以  $[Y - EY]^2$  代  $Y$ ,  $\epsilon^2$  代  $\epsilon$ , 并注意  $P((Y - EY)^2 \geq \epsilon^2) = P(|Y - EY| \geq \epsilon)$  即可.

现在转到定理 4.1 的证明. 利用契比雪夫不等式(4.4), 并注意

意  $E(\bar{X}_n) = \sum_{i=1}^n E(X_i)/n = na/n = a$ , 得

$$P(|\bar{X}_n - a| \geq \epsilon) \leq \text{Var}(\bar{X}_n)/\epsilon^2 \quad (4.5)$$

因为  $\bar{X}_n = \frac{1}{n}(X_1 + \dots + X_n)$  而  $X_1, \dots, X_n$  独立, 有

$$\text{Var}(\bar{X}_n) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n^2} n\sigma^2 = \sigma^2/n$$

以此代入(4.5), 得

$$P(|\bar{X}_n - a| \geq \epsilon) \leq \sigma^2/(n\epsilon^2) \rightarrow 0, \text{ 当 } n \rightarrow \infty$$

这证明了(4.2).

定理 4.1 的一个重要特例, 即前面提到的“频率收敛于概率”:

$$\lim_{n \rightarrow \infty} P(|p_n - p| \geq \epsilon) = 0 \quad (4.6)$$

这个定理是最早的一个大数定理, 是伯努利在 1713 年一本著作中证明的, 常称为伯努利大数定理.

大数定理的研究是概率论中一个很重要、古老且至今仍尚活跃的课题, 有许多深刻的结果. 例如, 不用假定  $X_i$  的方差存在也可以证明(4.2)式:  $X_1, X_2, \dots$  不必同分布甚至也可以不独立(当然仍得有一定限制), 收敛也可以改成其他更强的形式等. 这些都超出本书的范围之外.

在概率论中,大数定理常称为“大数定律”.这个字面上的不同,也不见得有很特殊的含义.但是,“定理”一词往往用于指那种能用数学工具严格证明的东西,而“定律”则不一定是这样.如牛顿的力学三大定律,电学中的欧姆定律之类.这牵涉到一个从哪个角度去看的问题.像(4.2)式这样有确切数学表述,并能在一定的理论框架内证明的结果,称之为“定理”无疑是恰当的.可是,当我们泛泛地谈论“平均值的稳定性”(即稳定到理论上的期望值)时,这表述了一种全人类多年的集体经验,有些哲理的味道.且这种意识也远早于现代概率论给之以严格表述之前,因此,称之为“定律”也不算不恰当.

### 3.4.2 中心极限定理

中心极限定理的意义已在本节开始处阐述过了.如我们所曾指出的,这是指一类定理.下面的定理 4.2 是其中之一:

**定理 4.2** 设  $X_1, X_2, \dots, X_n, \dots$  为独立同分布的随机变量,  $E(X_i) = a, \text{Var}(X_i) = \sigma^2, 0 < \sigma^2 < \infty$ . 则对任何实数  $x$ , 有

$$\lim_{n \rightarrow \infty} P\left(\frac{1}{\sqrt{n\sigma}}(X_1 + \dots + X_n - na) \leq x\right) = \Phi(x) \quad (4.7)$$

这里  $\Phi(x)$  是标准正态分布  $N(0, 1)$  的分布函数, 即

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-t^2/2} dt \quad (4.8)$$

注意  $X_1 + \dots + X_n$  有均值  $na$ , 方差  $n\sigma^2$ . 故

$$(X_1 + \dots + X_n - na) / (\sqrt{n\sigma}).$$

就是  $X_1 + \dots + X_n$  的标准化, 即使其均值变为 0 方差变为 1, 以与  $N(0, 1)$  的均值方差符合.

(4.7) 告诉我们, 虽则在一般情况下我们很难求出  $X_1 + \dots + X_n$  的分布的确切形式, 但当  $n$  很大时, 可以通过  $\Phi(x)$  给出其近似值. 例如, 若已知  $a = 1, \sigma^2 = 4, n = 100$ . 要求  $P(X_1 + \dots + X_{100} \leq 125)$ . 因  $na = 100, \sqrt{n\sigma} = 20$ , 把事件  $X_1 + \dots + X_{100} \leq 125$  改写

为  $(X_1 + \cdots + X_{100} - 100)/20 \leq 1.25$ , 用(4.7)得到上述概率的近似值为  $\Phi(1.25) = 0.8944$ . 这里当然有一定的误差. 有许多研究工作就是为了估计这种误差, 也得出了一些深刻的结果. 但是, 这种误差估计要求对  $X_i$  的分布或其矩有一定的了解.

定理 4.2 通称为林德伯格定理或林德伯格-莱维定理, 是这两位学者在本世纪 20 年代证明的. “中心极限定理”的命名也是始于这个时期, 它是波伊亚在 1920 年给出的. 但定理 4.2 并非最早的中心极限定理. 历史上最早的中心极限定理是定理 4.2 的一个特例, 即当  $X_i$  由(1.20)式定义时, 这时, 如以前多次指出的,  $X_1 + \cdots + X_n$  就是某事件  $A$  在  $n$  次独立试验中发生的次数. 这个特例很重要, 值得单独列为一条定理.

**定理 4.3** 设  $X_1, X_2, \cdots, X_n, \cdots$  独立同分布,  $X_i$  分布是

$$P(X_i = 1) = p, P(X_i = 0) = 1 - p, 0 < p < 1$$

则对任何实数  $x$ , 有

$$\lim_{n \rightarrow \infty} P\left(\frac{1}{\sqrt{np(1-p)}}(X_1 + \cdots + X_n - np) \leq x\right) = \Phi(x) \quad (4.9)$$

定理 4.3 是定理 4.2 的特例, 只须注意  $E(X_i) = p, \text{Var}(X_i) = p(1-p)$ . 又此处  $X_1 + \cdots + X_n$  服从二项分布  $B(n, p)$ , 故定理 4.3 是用正态分布去逼近二项分布. 在第二章例 1.2 曾指出过用波哇松分布逼近二项分布. 二者的应用不同: (4.9) 用于  $p$  固定, 因而当  $n$  很大时  $np$  很大. 而波哇松逼近则用于  $p$  很小(可设想成  $p$  随  $n$  变化以趋向于 0)但  $np = \lambda$  不太大时. 共同之点是  $n$  必须相当大.

定理 4.3 称为棣莫弗-拉普拉斯定理, 是历史上最早的中心极限定理. 1716 年棣莫弗讨论了  $p = \frac{1}{2}$  的情形, 而拉普拉斯则把它推广到一般  $p$  的情形.

如果  $t_1, t_2$  是两个正整数,  $t_1 < t_2$ . 则当  $n$  相当大时, 按(4.9)近似地有

$$P(t_1 \leq X_1 + \cdots + X_n \leq t_2) \approx \Phi(y_2) - \Phi(y_1) \quad (4.10)$$

其中

$$y_i = (t_i - np) / \sqrt{np(1-p)}, \quad i = 1, 2 \quad (4.11)$$

我们指出:若把  $y_1, y_2$  修正为

$$\begin{aligned} y_1 &= \left( t_1 - \frac{1}{2} - np \right) / \sqrt{np(1-p)} \\ y_2 &= \left( t_2 + \frac{1}{2} - np \right) / \sqrt{np(1-p)} \end{aligned} \quad (4.12)$$

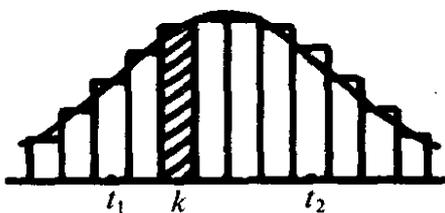


图 3.7

再应用公式(4.10),则一般可提高精度.其道理可以从图 3.7 看出.此图中每一矩形小条底边长为 1,底边中点为非负整数  $k$ ,而矩形的高,就是  $P(X_1 + \cdots + X_n = k)$ ,即二项概率  $b(k; n, p)$ .图中的曲线则是正态分布  $N(np, np(1-p))$

的密度函数的曲线.近似式(4.10)的意思,无非是用这曲线下的面积来近似代替这些矩形条的面积.可是细看图形 3.7,可知,包括点  $t_1, t_1 + 1, \cdots, t_2$ ,这些小条在横轴上所占范围,是左起  $t_1 - 1/2$ ,右止  $t_2 + 1/2$ ,故曲线下的面积,也应在这两个起止点之间去计算.这就是修正公式(4.12)的来由.当  $n$  很大时,这个修正并不很重要,但在  $n$  不太大时则有比较大的影响.

**例 4.1** 设某地区内原有一家小型电影院,因不敷需要,拟筹建一所较大型的.设据分析,该地区每日平均看电影者约有  $n = 1600$  人,且预计新电影院建成开业后,平均约有  $3/4$  的观众将去这新影院.

现该影院在计划其座位数时,要求座位数尽可能多,但“空座达到 200 或更多”的概率又不能超过 0.1.问设多少座位为好?

设把每日看电影的人排号为  $1, 2, \cdots, 1600$ ,且令

$$X_i = \begin{cases} 1, & \text{若第 } i \text{ 个观众去新影院} \\ 0, & \text{若不然} \end{cases} \quad i = 1, \cdots, 1600$$

则按假定有  $P(X_i = 1) = 3/4, P(X_i = 0) = 1/4$ . 又假定各观众去不去电影院系独立选择, 则  $X_1, X_2, \dots$  是独立随机变量.

现设座位数为  $m$ , 则按要求

$$P(X_1 + \dots + X_{1600} \leq m - 200) \leq 0.1$$

在这个条件下取  $m$  最大. 这显然就是在上式取等号时, 因为  $np = 1600 \cdot (3/4) = 1200, \sqrt{np(1-p)} = 10\sqrt{3}$ , 按 (4.12) 的修正,  $m$  应满足条件

$$\Phi\left(\left(m - 200 + \frac{1}{2} - 1200\right) / (10\sqrt{3})\right) = 0.1$$

查  $\Phi(x)$  的表得知, 当  $\Phi(x) = 0.1$  时,  $x = -1.2816^*$ . 由

$$(m - 200 + 1/2 - 1200) / (10\sqrt{3}) = -1.2816$$

定出  $m = 1377.31 \approx 1377$ . 在本例中, (4.12) 式的修正没有什么影响.

直到本世纪 30 年代, 中心极限定理的研究曾是概率论的一个重要内容, 至今仍是一个活跃的方向. 推广的方向如独立不同分布以至非独立的情形, 由中心极限定理而引起的误差的估计, 以及与之相关联的问题如大偏差问题之类.